

Universidade de Lisboa
Instituto de Geografia e Ordenamento do Território



**Classificação de uso e ocupação do solo através de análise da mistura
espectral**

Joana Sofia Vicente da Silva

Dissertação orientada pelo Professor Doutor Fernando Jorge Pedro da Silva
Pinto da Rocha e pelo Professor Doutor José António Pereira Tenedório

Mestrado em Sistemas de Informação Geográfica e Modelação Territorial
Aplicados ao Ordenamento

2021

Universidade de Lisboa
Instituto de Geografia e Ordenamento do Território



**Classificação de uso e ocupação do solo através de análise da mistura
espectral**

Joana Sofia Vicente da Silva

Dissertação orientada pelo Professor Doutor Fernando Jorge Pedro da Silva
Pinto da Rocha e pelo Professor Doutor José António Pereira Tenedório

Júri:

Presidente: Professora Doutora Patrícia Catarina dos Reis Macedo Abrantes
do Instituto de Geografia e Ordenamento do Território da Universidade de
Lisboa

Vogais:

- Professora Doutora Cristina Delgado Henriques da Faculdade de
Arquitetura da Universidade de Lisboa
- Professor Doutor Fernando Jorge Pedro da Silva Pinto da Rocha do
Instituto de Geografia e Ordenamento do Território da Universidade de
Lisboa

Esta dissertação integra-se no âmbito da investigação desenvolvida no projeto TRIAD - *health Risk and social vulnerability to Arboviral Diseases in mainland Portugal* (PTDC/GES-OUT/30210/2017).

Agradecimentos

Gostaria de agradecer a todos os que estiveram por perto e me acompanharam neste meu caminho.

Ao meu orientador, Professor Doutor Jorge Rocha, um muito obrigado pela orientação, paciência, apoio, incentivo, e por todo o conhecimento transmitido sobre este tema ao longo destes dois anos.

À minha família, por todo o carinho e apoio incondicional dado ao longo destes anos, em especial à minha avó que me criou como se fosse minha mãe. Aos tios e primos que estiveram sempre lá no momento certo.

Ao meu namorado que me ajudou a distrair nos momentos mais difíceis e que me aturou nos momentos mais stressantes de ansiedade, sem ele não teria conseguido. Obrigada do fundo do coração, pela motivação para terminar a tese e pela ajuda nesta fase tão importante das nossas vidas.

A todos que passaram pela minha vida profissional e estudantil, que me ensinaram diversas coisas, que me fizeram evoluir enquanto pessoa e profissional.

Resumo

Os territórios estão em constante mudança e para tal, é necessário acompanhar o presente ou seja, o nosso passado amanhã. Neste sentido, a detecção remota e a cartografia de ocupação e uso de solo são uma importante fonte de informação para avaliar a evolução de fenómenos com relevância para o planeamento e ordenamento do território.

Nesta dissertação explorou-se uma técnica de classificação baseada no *subpixel*, nomeadamente a Análise de Mistura Espetral (AME), de modo a caracterizar os padrões de ocupação, aplicando-se o modelo VIS (vegetação-impermeável-solo) para analisar a estrutura do uso e ocupação do solo em contexto rural. O modelo VIS, proposto por Ridd em 1995, é um modelo conceptual que define os ambientes através de uma combinação de três componentes básicos constituintes de qualquer área sendo eles a vegetação (V), impermeável (I) e solo (S).

A área escolhida pertence ao Alentejo e é constituída por doze freguesias pertencentes ao distrito de Beja. Os resultados da classificação da aplicação da Análise de Mistura Espetral (AME), obtidos através de imagens de satélite LandSat8 e Sentinel2 são comparados entre si para avaliar os efeitos da resolução espacial neste tipo de classificação. Paralelamente os resultados obtidos são avaliados por comparação com dados oficiais da carta de uso e ocupação do solo de 2018 (COS2018). A necessidade de se realizar uma análise ao subpixel prende-se essencialmente com a presença de variabilidade intrínseca na imagem, originando pixéis impuros.

Um dos problemas mais comuns em Detecção Remota é a dificuldade de distinção entre o solo e o impermeável, e o mesmo se verificou neste trabalho. O impermeável é constituído por materiais que estão presentes no solo exposto, provocando confusão espectral.

Através da criação de áreas de treino “ensinamos” o *software* a distinguir e a identificar os diferentes usos do solo, servindo de base para todo o processo de classificação. Estas áreas de treino devem ser as mais puras espectralmente, de modo a representar da melhor forma a realidade existente na superfície terrestre.

Palavras-chave: Análise de Mistura Espetral, Classificação Supervisionada, *pixels* impuros, *subpixel* e Modelo VIS

Abstract

Territories are constantly changing and for that, it is necessary to follow the present, that is, our past tomorrow. In this sense, remote sensing and land use and occupation cartography are an important source of information for assessing the evolution of phenomena, necessarily for the spatial planning.

In this dissertation, a classification technique based on the subpixel was explored, namely the Spectral Mixture Analysis (SMA), in order to characterize the occupation patterns, applying the VIS model (vegetation-impermeable-soil) to analyze the structure of the land use and occupation in a rural context. The VIS model, proposed by Ridd in 1995, is a conceptual model that defines environments through a combination of three basic components that make up any area, namely vegetation (V), impermeable (I) and soil (S).

The chosen area belongs to the Alentejo and is found by twelve parishes belonging to the district of Beja.

The results of the classification using the application of the Spectral Mixture Analysis (SMA), obtained through satellite images LandSat8 and Sentinel2 are compared with each other to evaluate the effects of the spatial resolution in this type of classification. In parallel, the results obtained are evaluated by comparison with official data from Carta de Ocupação de Solo (COS2018). The need to perform a sub-pixel analysis is essentially related to the presence of intrinsic variability in the image, resulting in impure pixels.

One of the most common problems in Remote Sensing is the difficulty of distinguishing between the soil and the impermeable, and the same was verified in this work. The impermeable is constituted by materials that are present in exposed soil, causing spectral confusion.

Through the creation of training areas, we “teach” the software to distinguish and identify the different uses of the soil, serving as a basis for the entire classification process. These training areas should be the most spectrally pure, in order to best represent the reality on the Earth's surface.

Keywords: Spectral Mixing Analysis, Supervised Classification, impure *pixels*, *subpixel* and VIS Model

Índice

1	Introdução	1
2	Deteção Remota e classificação de imagem	3
2.1.	Princípios	3
2.2.	Classificação de imagem	7
2.1.1	Classificação supervisionada	10
2.1.2	Classificação não supervisionada	11
2.2	O problema dos <i>mixels</i>	12
2.3	Classificação do <i>subpixel</i> e a análise de Mistura Espectral (AME)	15
2.3.1	Modelo VIS	17
3	Análise de Uso e Ocupação do solo. Caso de estudo	23
3.1	Área de estudo	23
3.2	Dados	24
3.3	Componentes do solo (VIS) e percentagens de pertença	28
3.4	Análise de uso e ocupação do solo	32
3.5	Comparação entre os resultados e a COS 2018	40
4	Considerações finais	48
5	Bibliografia	50

Índice de figuras

Figura 1 - Espectro eletromagnético.....	3
Figura 2 – Janelas atmosféricas.....	4
Figura 3 - Matrizes correspondentes a imagens em várias bandas do espectro.....	4
Figura 4 - Diferentes resoluções espaciais, 30 m do LandSat8 (a) e 10 m do Sentinel2 (b)	5
Figura 5 - Diferentes resoluções radiométricas	6
Figura 6 – Relação entre resolução espacial e temporal: exemplos de aplicações	7
Figura 7 - Processo da classificação em detecção remota.....	9
Figura 8 – Campo instantâneo de visão (IFOV)	13
Figura 9 – Pixels impuros (mixels)	14
Figura 10 - Conceito de Mistura Espectral Linear	16
Figura 11 - Duas abordagens para a distinção das composições de solo e vegetação. a) Richardson e Wiegand, 1977; b) depois Kauth e Thomas, 1976.....	18
Figura 12. Representação de alguns usos urbano e suburbano do modelo V-I-S.....	21
Figura 13 - Área de estudo	23
Figura 14 - Composição colorida da imagem satélite Sentinel2 utilizada.....	25
Figura 15 – Composição colorida da imagem de satélite LandSat8 utilizada	25
Figura 16 - Assinaturas espectrais dos componentes do solo para as imagens de satélite Sentinel2 (a) e LandSat8 (b)	30
Figura 17 - Componentes VIS das imagens LandSat8 e Sentinel2	31
Figura 18 - Resultados da classificação com a distinção de pixels puros e mixeis.....	33
Figura 19 - Resultados finais obtidos após a classificação	35
Figura 20 - Diagrama triangular do Modelo VIS para as freguesias - LandSat8	37
Figura 21 - Diagrama triangular do Modelo VIS para as freguesias - Sentinel2.....	37
Figura 22 - Variação da composição de VIS em cada classe uso devido à variação de resolução	38
Figura 23 - Carta de Ocupação do solo (2018) nível I	43

Figura 24 - Carta de Ocupação do solo (2018) nível I de acordo com a agregação das classes para comparação com o Modelo VIS	46
--	----

Índice de tabelas

Tabela 1 - Caracterização administrativa da área de estudo.....	24
Tabela 2 - Características do LandSat 8.....	26
Tabela 3 - Características do Sentinel2	27
Tabela 4 - Comparação entre os satélites LandSat 8 e Sentinel2	27
Tabela 5 - Análise do comportamento espectral dos pixels decorrente da classificação	33
Tabela 6 - Diferenças entre as classificações de imagens de satélite LandSat8 e Sentinel2	34
Tabela 7 - Quadro de referência de códigos e respectivas freguesias	35
Tabela 8 - Percentagens da composição do Modelo VIS para cada freguesia e sua variação relativa ao aumento de resolução	39
Tabela 9 - Características dos ortofotos.....	41
Tabela 10 - Dados auxiliares utilizados na produção da COS.....	42
Tabela 11 - Áreas das classes de Ocupação do solo na área de estudo.....	43
Tabela 12 - Descrição das classes da Carta de Uso e Ocupação do Solo 8	45
Tabela 13 - Correspondência entre as classes do Modelo VIS e da COS 2018 (nível I).....	46
Tabela 14 - Comparação entre os valores obtidos pela classificação e classes da COS 2018 (ha)	

1 Introdução

Desde sempre a Humanidade procura um conhecimento geográfico do mundo. Para tal, os locais mais altos foram os mais apelativos (montanhas, torres de fortalezas, edifícios altos, etc.) para a observação da maior área geográfica possível, e deste modo perceber de forma antecipada os perigos que poderiam acontecer.

Atualmente o objetivo continua igual, apenas os pontos de análise são diferentes. As principais observações da superfície terrestre são obtidas através de técnicas de Detecção Remota como as fotografias aéreas e as imagens de satélite.

Nesta dissertação, o foco são as imagens de satélite que traduzem um poderoso meio de obtenção de informação atualizada e a custos relativamente baixos. A imagem de satélite apresenta-se eficaz na análise e tratamento de áreas de grande dimensão (escala global, nacional e regional), mais especificamente de unidades de uso e ocupação do solo, geológicas, morfológicas e biogeográficas.

Os dados de uso e ocupação de solo são importantes fontes para variadas aplicações, seja para estudos da evolução do ambiente urbano ou rural, do ordenamento e planeamento do território, socioeconómicos, entre outros. Contudo, a classificação de ocupação e uso do solo é ainda um desafio, perante a complexa paisagem e a limitação dos dados obtidos por deteção remota.

Uma dessas limitações, principalmente quando falamos de estudos de áreas urbanas, prende-se com a adaptação das diferentes resoluções às áreas em estudo, por exemplo a resolução espacial ainda pode ser um fator limitativo. Contudo não podemos centrar todos os esforços de melhoria das classificações apenas neste fator. Os algoritmos tradicionais pixel-a-pixel não estão adaptados às características de todos os objetos à superfície terrestre, visto que têm em conta apenas as assinaturas espectrais. No entanto, este problema pode ser colmatado com informação auxiliar. Esta informação

auxiliar inclui qualquer tipo de informação, espacial ou não, que possa ser usada para a classificação (declives, altitudes, geologia, redes, etc.). (Rocha, J., Sousa, P., 2007)

Devido à confusão da assinatura espectral de alguns tipos de usos de solo existe a possibilidade de serem criados erros de classificação, por exemplo, entre superfície impermeável e solo e áreas dispersamente povoadas com floresta. Contudo, as resoluções espaciais, temporais e espectrais dos dados de satélite são um poderoso aliado para a criação de informação sobre as características físicas do meio, fornecendo informação sobre os objetos à superfície como, a sua forma, tamanho, e taxas de variação dos elementos. (Matos, J.,2016)

Nesta dissertação pretende-se testar a estabilidade de um método de modelação de mistura espectral, aplicando o modelo VIS (vegetação-impermeável-solo) para analisar a estrutura do uso e ocupação do solo em contexto rural. Os resultados da classificação da aplicação da Análise de Mistura Espectral (AME), obtidos através de imagens de satélite LandSat8 e Sentinel2, foram avaliados por comparação com dados oficiais da carta de uso e ocupação do solo de 2018 (COS2018). Paralelamente, os resultados da análise com LandSat8 e Sentinel2 são comparados entre si para avaliar os efeitos da resolução espacial neste tipo de classificação.


A dissertação estrutura-se nos seguintes capítulos: Detecção Remota e classificação de imagem, onde são explanados os princípios básicos, os tipos de classificação, modelo conceptual e técnicas utilizadas; Análise de Uso e Ocupação do solo e o Caso de estudo em que identifica área de estudo, os dados, a explicação dos componentes utilizados e os resultados obtidos na classificação com a sua comparação com os dados da COS2018 e por fim, as Considerações finais onde são explicados, de formas sucinta, os resultados obtidos nesta dissertação e possíveis melhoramentos.

2 Detecção Remota e classificação de imagem

2.1. Princípios

A deteção remota consiste no processo de aquisição de informação relativa a um determinado fenómeno sem que para isto, exista um contacto físico entre este e o dispositivo de medição. Atualmente, é apenas utilizado este termo quando aplicado a sensores de radiação eletromagnética orbitais.

Com os sensores passivos, utiliza-se normalmente a parte do espectro eletromagnético que inclui a amplitude de comprimentos de onda no domínio do visível e parte do infravermelho, como se encontra representado na Figura 1. Os sensores ativos, por seu turno, utilizam a parte do espectro correspondente às micro-ondas recorrendo a tecnologia radar.




(Adaptado de Matos, J., 2016)

Figura 1 - Espectro eletromagnético

A deteção remota baseia-se na radiação emitida ou refletida pelos objetos. Neste contexto, as janelas atmosféricas adquirem particular importância pois são as zonas do espectro de radiação eletromagnética para as quais existe transmissão através da atmosfera. Fora destas, a energia eletromagnética é convertida noutra forma de energia


por interação com a matéria, por exemplo, a radiação ultravioleta é absorvida pelo ozono e como tal, não é utilizada em deteção remota.



(Adaptado de Matos, J., 2016)

Figura 2 – Janelas atmosféricas

Os sensores captam determinadas partes do espectro de energia eletromagnética, refletida ou emitida, provenientes dos objetos presentes na superfície terrestre e convertem essa energia num sinal numérico. Ou seja, captam a radiação numa determinada banda e armazenam a intensidade do valor recebido numa célula de uma matriz, denominada *pixel*, que consiste no elemento mais pequeno existente nessa mesma matriz (imagem). Este valor designa-se por nível radiométrico e representa um número inteiro, variando de 0 a 255 nas imagens de 8 bits (2^8). Uma matriz consiste num conjunto de *pixels* referenciados em linha e coluna (Figura 3).



(Adaptado de Matos, J., 2016)

Figura 3 - Matrizes correspondentes a imagens em várias bandas do espectro

Nos satélites LandSat8 e Sentinel2 existem sensores, presentes nas plataformas orbitais, para diferentes bandas do espectro eletromagnético, designando-se assim, multiespectral. Ou seja, existe uma matriz para cada banda espectral, as quais no seu conjunto formam uma imagem (Figura 3).

Os sensores podem ser caracterizados pelas suas resoluções (capacidade de um sistema ótico de diferenciar objetos):

1) Resolução espacial (Figura 4), corresponde à dimensão captada por uma célula do sensor, ou seja, a menor dimensão registada (*pixel*), expressa em metros, quanto maior a resolução espacial, menor é o tamanho do *pixel*;



Figura 4 - Diferentes resoluções espaciais, 30 m do LandSat8 (a) e 10 m do Sentinel2 (b)

2) Resolução espectral corresponde ao número bandas espectrais às suas passíveis de registo pelo sensor;

3) Resolução radiométrica é definida pela capacidade do sensor de diferenciar a energia eletromagnética que recebe, expressa em bits (Figura 5);

Memoria de Processamento Imagem (bits)	Nº Máximo de Cores Disponíveis no Monitor	
1	2	Preto e branco
2	4	
3	8	
4	16	
5	32	
6	64	
7	128	
8	256	
9	512	
10	1024	
11	2048	
12	4096	
13	8192	
14	16384	
15	32768	
16	65536	
17	131072	
18	262144	
19	524288	
20	1048576	
21	2097152	
22	4194304	
23	8388608	
24	16777216	

(Extraído de Jensen, J.R, 2005)

Figura 5 - Diferentes resoluções radiométricas

4) Resolução temporal consiste no intervalo entre duas passagens consecutivas do sensor pelo mesmo ponto (Figura 6).

Nas secções seguintes analisaremos as diferenças de resoluções entre satélites e a forma como podem afetar a classificação de uma imagem.

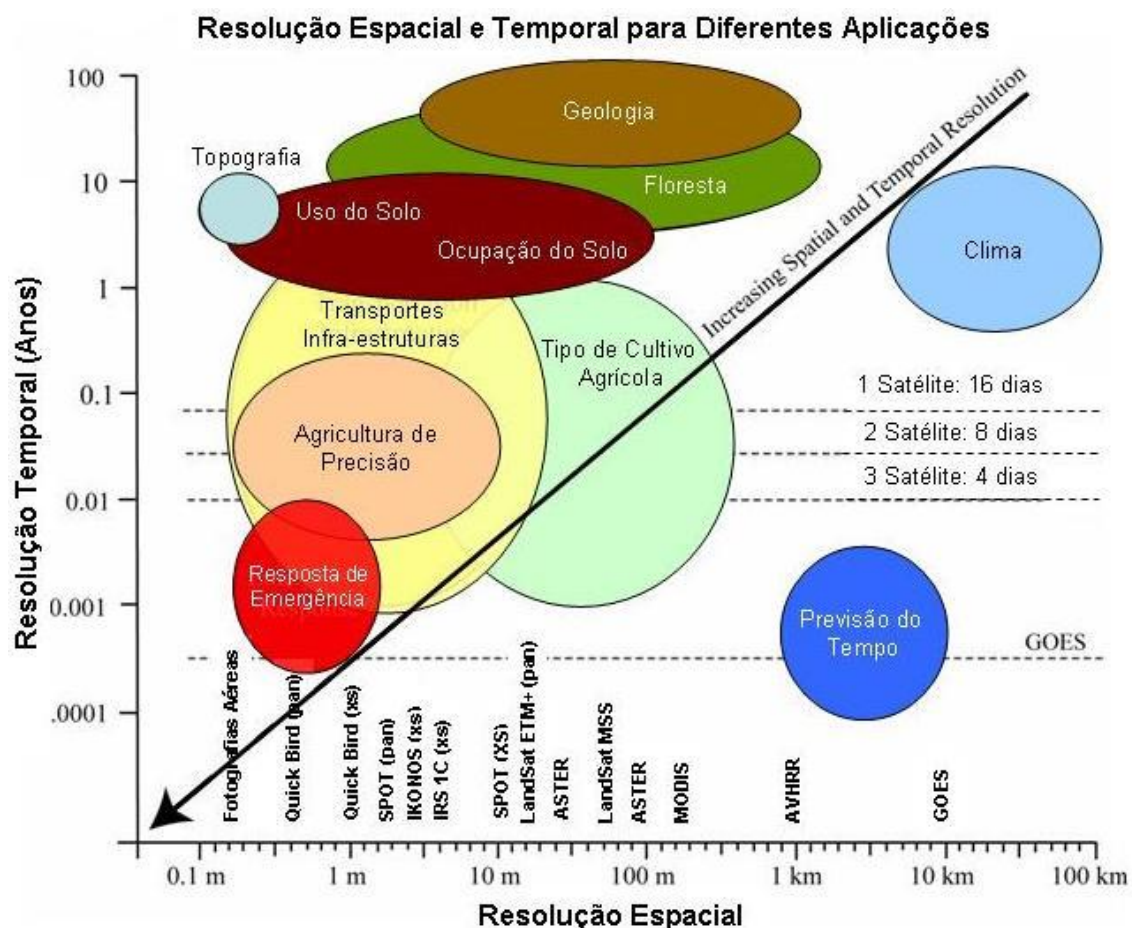


Figura 6 – Relação entre resolução espacial e temporal: exemplos de aplicações

2.2. Classificação de imagem

Os dados de detecção remota apresentam diferentes resoluções espaciais, espectrais, radiométricas e temporais. Portanto, é fundamental perceber os pontos fortes e fracos dos diferentes tipos de dados provenientes dos sensores de forma a facilitar a seleção adequada para classificação de imagem. Os sensores óticos a bordo dos satélites operacionais permitem um meio eficiente para quantificar as distribuições da ocupação humana, tanto no passado (dados históricos) como no presente, avaliando ao mesmo tempo as propriedades físicas dos objetos e a sua reflectância.

A classificação de imagens *pixel-por-pixel*, em detecção remota, utiliza a informação espectral representada por números digitais de uma ou mais bandas espectrais. O objetivo

é atribuir cada *pixel* de uma imagem a uma classe (*e.g.*, água, floresta, comercial, urbana, etc.), de forma a gerar um mapa temático. Sendo assim, cada *pixel* representa um conjunto de medições de reflectância de uma porção de terreno em várias bandas espectrais.

Neste sentido, é necessária a distinção entre a classe espectral e a classe temática. A primeira refere-se ao grupo de *pixels* que apresentam características uniformes ou semelhantes relativamente ao seu valor de brilho (*i.e.*, nível radiométrico) nas diferentes bandas espectrais da informação e a segunda indica a categoria de interesse em que o analista quer identificar na imagem.

Normalmente, considera-se duas versões de classificação de imagem: supervisionada e não-supervisionada. Na supervisionada, o analista identifica na imagem uma ou mais homogeneidades representativas de diversas classes para utilizar como “áreas de treino”. Cada *pixel* da imagem será posteriormente comparado a nível espectral com estas áreas de maneira a determinar a que classe deverá pertencer.

Na classificação não-supervisionada, primeiramente, são agrupadas as classes espectrais baseadas no seu nível radiométrico e proximidade. Posteriormente, será estabelecida por parte do analista uma correspondência de cada uma delas a uma classe temática.

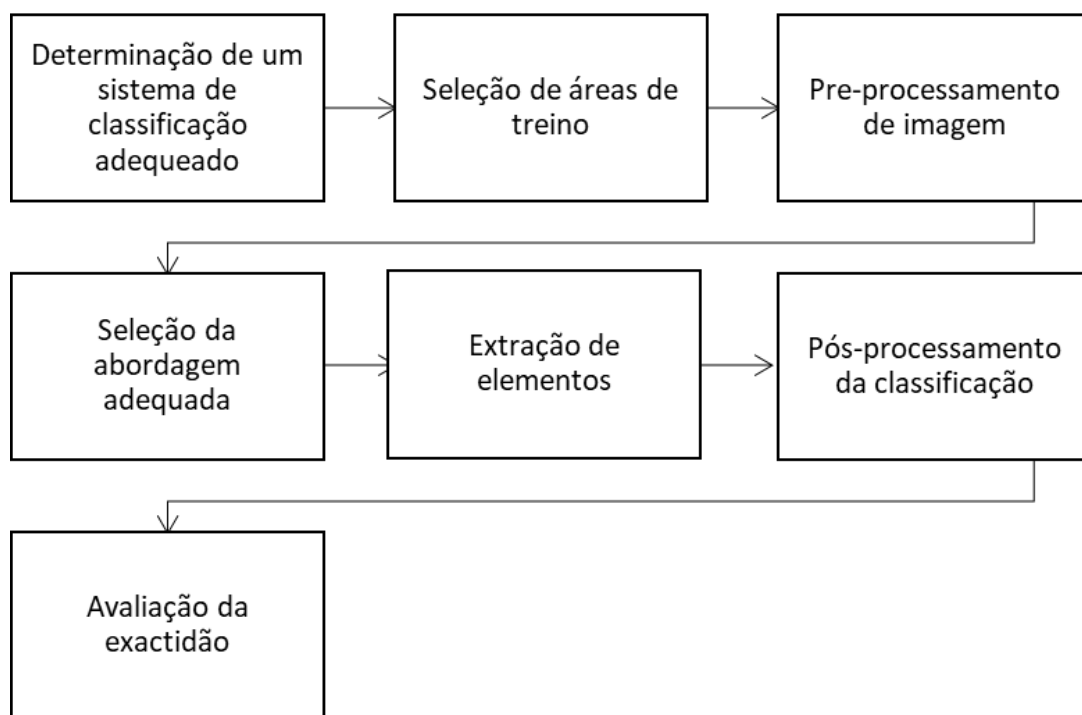
Em ambas as abordagens, cada *pixel* é atribuído a uma determinada classe com base na medição dos valores espectrais nas diversas bandas. A maioria das classificações são baseadas numa análise *pixel-por-pixel* (classificadores rígidos ou flexíveis), provocando erros de classificação devido à pouca importância dada ao ruído e à variabilidade intra-classe. Assim, de forma a minimizar esses erros, muitas vezes é utilizada a análise ao nível do *subpixel*.

Gerar uma classificação satisfatória a partir de uma imagem obtida por detecção remota não é uma tarefa fácil ou direta. Segundo Lu e Weng (2004), existem diversos fatores que influenciam este processo como, por exemplo, a complexidade das paisagens da

área de estudo, a existência de dados adequados, usos apropriados de variáveis e algoritmos de classificação e a experiência do analista.

A classificação de imagem é um processo complexo que pode ser afetado por outros fatores, tais como: seleção dos dados de detetados remotamente, processamento de imagem e abordagem da classificação, que influenciam o sucesso da mesma (Lu & Weng, 2007).

Os passos que se podem considerar como os mais gerais, na classificação de imagem em detecção remota são retratados na Figura 7. A escolha dos dados, desenho do procedimento e a qualidade dos resultados da classificação dependem dos objetivos e experiência do analista, da disponibilidade económica e da escala de análise.



(Adaptado de Lu e Weng, 2007)

Figura 7 - Processo da classificação em detecção remota

2.1.1 Classificação supervisionada

A classificação supervisionada predomina como método de classificação devido à complexidade de situações que ocorrem no globo terrestre e pelas técnicas de análise de dados clássicas.

Podemos distinguir 4 fases distintas neste processo, sendo a primeira a definição da nomenclatura, onde é estabelecida das classes de ocupação do solo, seguindo-se a fase de treino, a classificação e a apresentação e avaliação de resultados.

Fase de treino

O objetivo desta fase é obter uma descrição do comportamento espectral para cada classe de uso ocupação de solo, através de um conjunto de estatísticas que traduzem da melhor forma possível as suas características. É necessária uma análise da informação espectral contida na imagem para a delimitação das áreas de treino, sendo que esta serve de apoio e complemento ao conhecimento da área geográfica e de qualquer outra informação de referência. Resumindo, quanto mais apurado for o processo de treino, mais sucesso se obterá na fase da classificação e consequentemente, maior será o valor da informação gerada.

Existem várias abordagens para a delimitação de áreas de treino. Uma delas é a obtenção de informação, recolhida localmente, com apoio de coordenadas originadas pelo GPS - *Global Positioning System*. Noutra, a utilizada nesta dissertação, para obter as áreas de treino foram delimitados polígonos sobre a imagem por fotointerpretação, com recurso a uma composição colorida.

Os valores de brilho (*i.e.*, nível radiométrico) existentes dentro de cada área de treino vão ser extraídos de acordo com as coordenadas dos vértices dos polígonos delineados. Estes valores de brilho vão servir de amostra para o desenvolvimento da descrição estatística de cada área de treino.

Durante o processo de delimitação de áreas de treino deve se ter em conta que estes devem abranger toda a imagem, ou seja tornar a distribuição o mais homogénea possível de modo a favorecer a representatividade de toda a variabilidade intrínseca às classes de uso e ocupação do solo presentes na matriz de dados.

Deve-se proceder à afinação do conjunto de treino, durante o processo, de modo a garantir que existe qualidade global dos dados existentes em cada área de treino, seguindo-se a análise da sua separabilidade espectral recorrendo à representação gráfica de distribuições normais. As áreas de treino que incluam mais do que uma classe espectral são identificadas e delimitadas de novo.

Fase de classificação

Para o reconhecimento de padrões espectrais, têm sido apresentadas várias propostas de algoritmos representando diversas abordagens matemáticas possíveis. Para proceder à classificação de imagens os classificadores *pixel-por-pixel* supervisionados mais utilizados e aceites pela comunidade científica são os da *mínima distância*, da *máxima verossimilhança* e de *Bayes*.

2.1.2 Classificação não supervisionada

Segundo Schoenmakers (1995), a estratégia da classificação não supervisionada para a identificação das classes espectrais representadas numa imagem tem como base de pensamento que os *pixels* de uma certa classe se situam espectralmente perto uns dos outros e que, em oposição, os *pixels* de classes diferentes estariam separados de forma vinculada. Estes métodos não utilizam dados de treino como base para a classificação,

mas sim, algoritmos que analisam os *pixels* e os agregam num determinado número de classes, com base nos agrupamentos naturais (*clusters*) existentes na imagem.

As classes obtidas através dos métodos não supervisionados são classes espectrais; como são criadas somente com base nos agrupamentos naturais dos valores dos *pixels* a identidade das classes espectrais não é inicialmente conhecida. Este método distingue-se da classificação supervisionada, visto que nesta é exigida uma menor interação por parte do analista. Numa fase posterior à classificação, o analista deve confrontar a imagem resultante dos agrupamentos com alguma informação de referência (imagens de maior escala ou mapas de uso e/ou ocupação do solo) para determinar a identidade das classes espectrais.

Existe então, uma agregação de *pixels* espectralmente semelhantes num cluster, num espaço multiespectral. A distância euclidiana (normalizada ou não), a distância de Manhattan e o interponto são propostas de medidas de similaridade mais usadas, nos processos de *clustering*.

2.2 O problema dos *mixels*

Cada *pixel* representa uma porção da superfície terrestre e possui um nível radiométrico, que consiste no valor de intensidade resultante da medição da energia refletida ou emitida pela porção. Quando o *pixel* representa mais que uma classe de uso do solo, o seu nível radiométrico é a média de toda a área ocupada.

A medida da unidade de superfície que é representado pelo *pixel* é a resolução espacial definida pelo *Instantaneous Field of View* (IFOV) do sistema ótico do sensor (Figura 8). A resolução espacial influencia a probabilidade de cada *pixel* representar apenas uma classe de ocupação do solo. Quando uma imagem apresenta uma resolução espacial elevada (ex. \leq a 1 metro) a probabilidade de um *pixel* apresentar apenas uma classe é maior.

No entanto, a maioria das imagens de satélite possuem a resolução espacial média-baixa, o que aumenta a probabilidade de um *pixel* representar variabilidade intraclasses. Em termos práticos, é explicado pelo facto que a dimensão dos elementos (estradas, edifícios, água, relva, entre outros) existentes nas paisagens são, geralmente, inferiores à resolução espacial dos sensores, levando a que exista mais classes num único *pixel*.




Figura 8 – Campo instantâneo de visão (IFOV)

Assim, devido à heterogeneidade das paisagens e à limitação da resolução espacial é comum a ocorrência de *pixels* impuros ou misturados (*mixed pixels* -> *mixels*). Isto acontece quando um *pixel* representa mais que uma ocupação de solo e neste caso uma

classificação rígida não seria a melhor opção porque representaria apenas uma parte do *pixel* deixando de considerar as restantes.

Mixels são *pixels* que são constituídos por diferentes materiais da superfície, ou tipos de ocupação do solo dentro do espectro registado no IFOV do satélite (Figura 9). A análise de mistura espectral baseia-se na pressuposição que o espectro captado pelo satélite corresponde a uma combinação (Figura 9), linear ou não, de cada um dos componentes contidos no IFOV (Roberts *et al.*,1998).




Figura 9 – Pixels impuros (*mixels*)

Para aquilatar a Pureza Espectral Linear numa imagem de satélite, o princípio chave é a identificação dos potenciais membros finais que expliquem, adequadamente, a assinatura espectral da maioria dos *pixels*. Quando as imagens estão calibradas e com a correção atmosférica estes podem ser obtidos através de bibliotecas de valores obtidos à superfície, com o auxílio de um radiómetro. Caso contrário é possível extrair os membros finais da própria imagem, independentemente da calibração ou correção.

2.3 Classificação do *subpixel* e a análise de Mistura Espectral (AME)

Uma abordagem possível de classificação para solucionar este problema é, através dos classificadores flexíveis (soft), como a análise difusa (*fuzzy*) e a Análise de Mistura Espectral (AME). Nas classificações flexíveis é atribuído uma probabilidade de pertença a cada uma das classes de ocupação do solo a cada *pixel*. A análise *fuzzy* baseia-se numa perspectiva estatística enquanto a AME é baseada num modelo físico de mistura dos valores discretos dos padrões de resposta espectral.

Apesar de se aplicar bem a meios urbanos, inicialmente a AME foi desenvolvida para classificar ambientes naturais. A AME permite dividir, em percentagens, a existência de cada ocupação do solo representada em cada *pixel*. Assim, consegue-se definir as componentes de ocupação de solo de determinada área. Este modelo de base física consiste na modelação de um espectro misturado como uma combinação de espectros puros, chamados membros finais (*endmembers*) (Adams *et al.*, 1995).

A AME linear corresponde ao processo de resolução das frações dos membros finais, considerando que o espectro medido para cada *pixel* corresponde a uma combinação linear de espectros do membro final, que corresponde à mistura física de alguns componentes presentes na superfície, ponderada pela área total.

Para perceber a AME é importante recuperar das secções anteriores o conceito de Pureza Espectral Linear (PEL). Um espectro puro (membro final) resulta de quando os fótons interagem com um componente apenas. A sua identificação permite precaver a variabilidade de valores intrínseca na imagem, visto que a combinação linear destes é utilizada para modelar os mixeis em frações de membros finais/espectros puros.

A identificação de um conjunto de membros finais que origine uma decomposição aceitável da imagem é um processo de tentativa e erro. Caso exista uma variabilidade muito elevada na imagem a ser classificada poderá não ser viável a identificação de

membros finais apropriados para a definir uma PEL, levando a elevados erros médios quadráticos (*Root Mean Square Errors* – RMSE) e uma proliferação de valores incorretos.

Na existência de múltipla dispersão a mistura é potencialmente não-linear, exigindo modelos de mistura não-linear. Esta representa uma aposta acertada para certos tipos de vegetação. No entanto, segundo Gilabert *et al.* (2000) a mistura dos espectros de solo e de vegetação tende a ter um comportamento linear. A Figura 10 demonstra o conceito de AME linear em que a soma de todos os membros finais é igual a 100%.




Figura 10 - Conceito de Mistura Espectral Linear

Matematicamente, podemos representar a AME linear como o espectro impuro (P_λ) de um dado *pixel* que é modelado pelo somatório das frações (f_λ) dos (n) membros finais ($\epsilon_{i\lambda}$) contidos no IFOV:

$$P_\lambda = \sum_{i=1}^n f_i E_{i\lambda} + \epsilon_\lambda \quad (1)$$

onde λ representa a banda espectral, n o número de membros finais e ϵ os valores residuais.

Para um dado conjunto membros finais é possível modelar as suas frações dentro de um pixel. O ajustamento do modelo pode ser expresso como o erro nas frações f (ϵ_λ em cada comprimento de onda) ou ao longo de todas as bandas através do RMSE (Roberts *et al.*, 1998):

$$RMSE = \frac{1}{m} \sqrt{\sum_{i=1}^n \varepsilon_{i\lambda}} \quad (2)$$

onde m é o número de bandas.

O RMSE mede o grau de variabilidade espectral que é explicada pelos membros finais selecionados. Um *pixel* que apresente elevado erro auxilia a identificar quais são os componentes espectrais que não estão a ser bem representados no modelo (Bateson e Curtiss, 1996). Quanto melhor for a qualidade da PEL, maior a probabilidade dos espectros dos membros finais representarem cada *pixel* da imagem numa combinação linear.

O RMSE e o ε_{λ} são ferramentas importantes de diagnóstico. Os residuais positivos ocorrem quando os espectros medidos pelo sensor têm uma reflectância mais elevada do que P_{λ} , indicando que P_{λ} contem características de absorção em falta na assinatura medida. ε_{λ} negativos indicam a comparência de características de absorção no espectro medido que estão ausentes ou são pouco pronunciadas no espectro modelado P_{λ} .

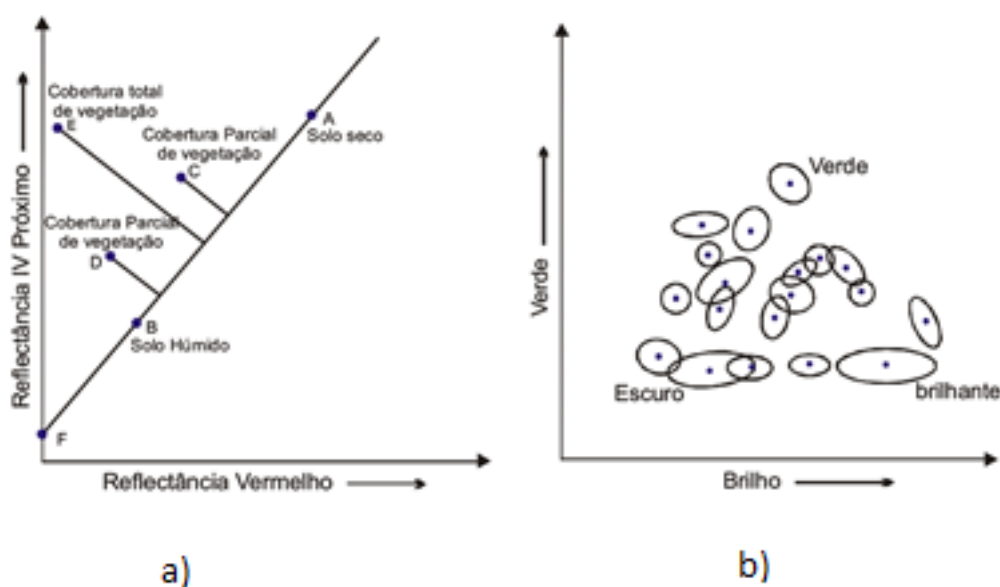
Uma forma de identificar quais os membros finais a extrair da imagem de satélite é utilizado o modelo conceptual VIS de Ridd.

2.3.1 Modelo VIS

Diversos investigadores, na área de deteção remota, têm desenvolvido uma variedade de abordagens com o objetivo de distinguir a cobertura da superfície em dados multiespectrais.

Existem vários modelos para explicar a ocupação do solo. John Adams, *et al.* (1995) utilizaram um modelo simples baseado em quatro membros finais. Este modelo consiste na reflexão espectral de vegetação verde, vegetação não-fotossintética, solo e sombra.

Richardson e Wiegand (1977) desenvolveram um modelo de tipo de vegetação perpendicular, como se verifica na Figura 11 a), que consiste no relacionamento positivo entre as reflectâncias na região do vermelho e infravermelho próximo, traduzindo-se numa reta que a imagem representa (ponto A ao F), designada como linha de solos. O aumento na cobertura da vegetação é representado através do aumento da distância perpendicular à linha dos solos.



(Extraído de Rocha, Morgado, & Tenedório, 2007)

Figura 11 - Duas abordagens para a distinção das composições de solo e vegetação. a) Richardson e Wiegand, 1977; b) depois Kauth e Thomas, 1976

Em 1976, Kauth e Thomas, desenvolveram transformações ortogonais de imagens em bruto e que resultaram elipses que representam os *clusters* espectrais dos *pixels* à volta dos valores médios de brilho e verde.

Existem muitas outras abordagens de classificação que incluem a incorporação de informação geográfica (Harris e Ventura, 1995), elementos de textura (Myint, 2001), classificações *fuzzy* (Zhang e Foody, 2001) e a junção de informação multisensor e/ou multi-resolução, como o radar (Haack *et al.*, 2002)

Para certas aplicações de detecção remota, tal como a monitorização de alterações de ocupação do solo, é essencial a capacidade de comparar classes entre diferentes imagens. A dificuldade em obter sucesso na classificação de imagens multiespectrais usando as técnicas supervisionadas e não-supervisionadas convencionais, tem decorrido da complexidade de obter classes consistentes em imagens obtidas em diferentes momentos, devido à variabilidade na iluminação, aos efeitos atmosféricos, e à resposta do sensor.

O crescente interesse pela composição biofísica dos ambientes terrestres emerge a necessidade de padronizar estes em parâmetros, o qual o modelo Vegetação-Impermeável-Solo (V-I-S) representa a solução proposta por Ridd.


Como o modelo V-I-S tem aplicabilidade em imagens de satélite, permite uma caracterização universal dos ambientes complexos como o interface urbanos/periferia, e a comparação da morfologia urbana dentro e entre cidades (Ridd, 1995). Este modelo conceptual tornou-se um poderoso aliado na percepção do modelo de crescimento das cidades, detecção das alterações urbanas e estudo dos impactos ambientais da urbanização.

Ridd aplicou o projeto-piloto na área metropolitana de Salt Lake City em que os dados foram amostrados ao longo de dois transectos lineares irradiando do centro da cidade com o objetivo de estudar a morfologia urbana, com base em imagens Landsat TM e fotografias aéreas.

Os ecossistemas urbanos são constituídos por uma heterogeneidade de materiais com diversas propriedades e interações complexas. Assim sendo, e tendo em conta essas propriedades, o modelo consiste numa representação da superfície urbana como uma combinação linear de três grupos fundamentais (exceptualizando a água): materiais de superfície impermeáveis, vegetação verde e solo exposto. Estas três substâncias impactam de forma significativa as dinâmicas e distribuição de reflectância na complexidade urbana, o que permite a sua distinção e mapeamento.

Os impactos das alterações de ocupação do solo variam em resposta a três fatores: a natureza das condições originais e das alterações urbanas e do tempo. O modelo V-I-S desenvolve um meio de medição para estas alterações e permite, conseqüentemente, o seu mapeamento. Tem como objetivo identificar e caracterizar o padrão de ocupação do solo ao longo do espaço para servir fins científicos de ecologia/biofísica (Ridd, 1995). Contudo, a pretensão do modelo VIS não é identificar áreas com classes de ocupação do solo bem definidas, mas sim caracterizar as variações de padrões de ocupação no território.

De acordo com a Figura 12, entendem-se as dinâmicas de alteração dos usos urbano e suburbano do modelo V-I-S. O processo de urbanização em ambientes de floresta ou produção agrícola favorece a conversão em superfícies impermeáveis em detrimento da vegetação. A urbanização em ambientes desérticos diminui a percentagem de solo convertendo-se em superfície impermeável. Dependendo do tipo de construção urbanística, que sucede à paisagem original, o tipo de material na conversão varia dependendo de se o uso final é o comercial, o industrial ou o residencial. A velocidade de conversão depende muito do fator humano e natural, ou seja, as superfícies impermeáveis têm tendência a se expandir mais rapidamente do que a componente vegetação.



(Extraído de Rocha, Morgado, & Tenedório, 2007)

Figura 12. Representação de alguns usos urbano e suburbano do modelo V-I-S

Ao longo do eixo V-I verifica-se uma sequência tipicamente residencial muito específica de muitas cidades do mundo desenvolvido. Perto do eixo I-S, o comércio tradicional e áreas industriais são as ocupações mais características. Mas, dependendo da quantidade de vegetação presente, os parques industriais e de investigação são tipicamente “arrastados” para a esquerda. Devido ao facto de diversas categorias de uso e ocupação do solo, por exemplo escolas, parques ou indústria poderem ser encontradas em qualquer sítio no diagrama V-I-S, está demonstrada a necessidade da classificação de ocupação do solo baseada em composições. É importante salientar o facto de que apenas a ocupação do solo pode ser obtida por detecção remota devido à sua capacidade de gerar uma assinatura espectral, e não o uso que apenas pode ser inferido pelo interpretador.

3 Análise de Uso e Ocupação do solo. Caso de estudo

3.1 Área de estudo

A área de estudo abrange parte do território pertencente ao distrito de Beja. Os municípios de Alvaro e Ferreira do Alentejo estão compreendidos, na totalidade, na área em estudo (Figura 15). Neste estudo estão incluídas doze freguesias, comtemplando 117 803,54 hectares (Tabela 4).

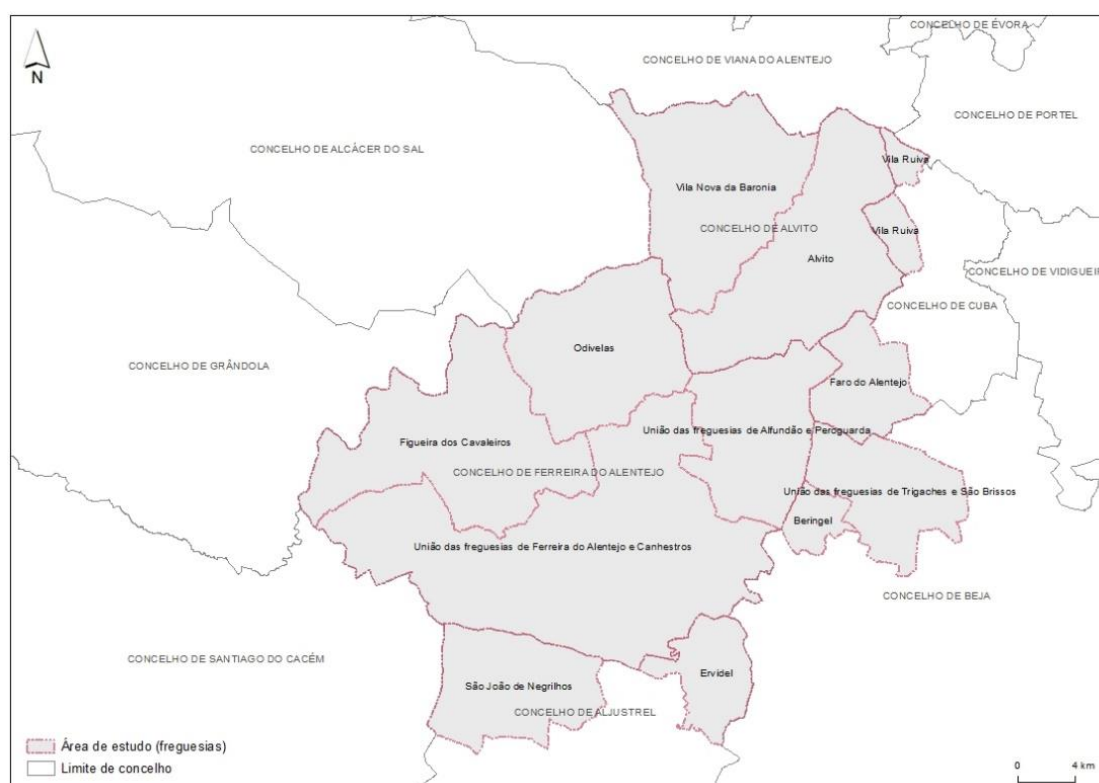


Figura 13 - Área de estudo

Tabela 1 - Caracterização administrativa da área de estudo

Freguesia	Concelho	Distrito	Área (ha)
São João de Negrilhos	Aljustrel	Beja	7 701,84
Ervidel	Aljustrel	Beja	3 885,08
Alvito	Alvito	Beja	13 652,34
Vila Nova da Baronia	Alvito	Beja	12 832,98
Beringel	Beja	Beja	1 604,96
União das freguesias de Trigaches e São Brissos	Beja	Beja	6 825,93
Faro do Alentejo	Cuba	Beja	4 467,51
Vila Ruiva	Cuba	Beja	2 012,23
União das freguesias de Ferreira do Alentejo e Canhestros	Ferreira do Alentejo	Beja	29 562,16
União das freguesias de Alfundão e Peroguarda	Ferreira do Alentejo	Beja	8 833,2
Figueira dos Cavaleiros	Ferreira do Alentejo	Beja	15 420,19
Odivelas	Ferreira do Alentejo	Beja	11 005,13

3.2 Dados

Para a análise de uso e ocupação de solo, optou-se por trabalhar dados multiespectrais com resoluções distintas para perceber o efeito destas no resultado final. Os dados utilizados para este trabalho foram as imagens Sentinel-2A (Figura 13) e LandSat (8) OLI (Figura 14), de Maio de 2018, ambas obtidas com céu limpo. As imagens utilizadas têm uma resolução espacial de 30 m e 10 m, o que se pode traduzir num obstáculo à existência de um *pixel* que apenas represente uma classe.



Figura 14 - Composição colorida da imagem satélite Sentinel2 utilizada




Figura 15 – Composição colorida da imagem de satélite LandSat8 utilizada

O satélite LandSat 8 também denominado LandSat Data Continuity Mission é o oitavo da série de satélites do Programa LandSat, sendo o sétimo destes a alcançar a órbita terrestre. Este satélite foi construído pela Orbital Sciences Corporation. Foi lançado em 11 de Fevereiro de 2013 e após 100 dias de operação foi entregue à USGS (United States Geological Survey). Na Tabela 1 podem-se observar as características gerais dos sensores instalados a bordo deste satélite

A missão Sentinel-2 tem uma órbita quase-polar e dispõe de um sensor MSI (*MultiSpectral Instrument*) com 13 bandas espectrais (Tabela 2), com grande resolução espacial (10, 20 ou 60 m, dependendo da banda) e uma resolução temporal de 10 dias com um satélite e de 5 dias apenas com os dois satélites operacionais.

Tabela 2 - Características do LandSat 8

Sensor	Bandas Espectrais	Resolução Espectral (nm)	Resolução Espacial	Resolução Temporal	Área Imagem	Resolução Radiométrica
OLI (Operational Land Imager)	B1 (Azul Costeiro)	0,43-0,45	30 m	16 dias	170 x 183 km	16 bits
	B2 (Azul)	0,45-0,51				
	B3 (Verde)	0,53-0,59				
	B4 (Vermelho)	0,64-0,67				
	B5 (Infravermelho Próximo)	0,85-0,88				
	B6 (Infravermelho Médio)	1,57-1,65				
	B7 (Infravermelho Médio)	2,11-2,29				
	B8 (Pancromática)	0,50-0,68	15 m			
	B9 (Cirrus)	1,36-1,38	30 m			
TIRS (Termal Infrared Sensor)	B10 (Infravermelho Termal)	10,6-11,19	100 m			
	B11 (Infravermelho Termal)	11,5-12,51				

Tabela 3 - Características do Sentinel2

Resolução	Nr da Banda	Nome da Banda	Comprimento de Onda Central (nanómetro)	Combinações de Bandas
10 m	B02	Blue (Azul)	490	Cor Verdadeira RGB 04/03/02 Falsa Cor 1 e 2 RGB 08/04/03 e 04/08/03
	B03	Green (Verde)	560	
	B04	Red (Vermelho)	665	
	B08	NIR (Infravermelho Próximo)	842	
20 m	B05	Red Edge 1	705	SWIR 1 RGB 12/11/8A
	B06	Red Edge 2	740	
	B07	Red Edge 3	783	
	B08A	Red Edge 4	865	
	B11	SWIR 1	1610	
	B12	SWIR 2	2190	
60 m	B01	Aerossol	443	--
	B09	Water Vapor	940	
	B10	Cirrus	1 375	

Recorrendo à Tabela 3 podemos comparar as características gerais de ambas as plataformas, LandSat e Sentinel.

Tabela 4 - Comparação entre os satélites LandSat 8 e Sentinel2

Características do Satélite	LandSat8	Sentinel 2
Instrumento/Sensor	OLI e TIRS	MSI (multi-spectral instrument)
Operadora/Instituição Responsável	NASA (National Aeronautics and Space Administration)	ESA (European Space Agency)
País	Estados Unidos	Europa
Situação Atual	Ativo	Ativo
Lançamento	2/11/2013	23 de junho de 2015
Altitude	705 Km	786 km
Inclinação	98,2°	98,56°
Órbita	Circular, Polar, Heliossíncrona	Circular, Heliossíncrona, descendente
Faixa Imageada	185 Km	290 Km
Horário da Passagem	10h / 12h	10 h 30 min
Período de Revisita	16 dias	5 dias
Resolução Espacial	Pancromático: 15 m Multiespectral: 30 m Termal: 100 m reamostrada para 30 m	10m, 20m, 60m
Resolução Radiométrica	16 bits	12 bits

3.3 Componentes do solo (VIS) e percentagens de pertença

Como se pretende usar o modelo VIS de Ridd, em que o solo e a vegetação juntamente com o impermeável, utilizou-se a AME linear de modo a analisar a composição da superfície através da análise dos mixeis. As Zonas húmidas e Massas de água foram excluídas desta análise devido à falta de correspondência com as classes do Modelo VIS. Foi utilizada a ferramenta UNMIX do Idrisi Selva para proceder à classificação.

Na primeira fase, definiu-se que temática queremos analisar e as suas componentes/classes que queremos diferenciar e classificar. Nesta dissertação será aplicado o modelo VIS, pelo que a temática é a classificação de uso e ocupação de solo, com base nas três classes mais generalistas do modelo: Vegetação (V), solos impermeabilizados (I) e solos a descoberto (S).

Sendo a área de estudo essencialmente rural, pretende-se estudar a aplicação deste modelo conceptual neste contexto. A vegetação inclui árvores, arbustos, relva e o solo impermeável abrange betão, metal, zinco e asfaltos. O solo para além do solo a descoberto inclui também a vegetação seca devido às suas características semelhantes de reflectância espectral e níveis radiométricos nas imagens de satélite.

Desta forma, criaram-se cerca de 19 polígonos de treino que correspondiam às classes pretendidas. Neste processo, teve-se o máximo cuidado, de modo a evitar zonas de fronteiras/transição entre dois tipos de uso e ocupação do solo (onde existe uma maior probabilidade de existência de “*pixels* misturados” (*mixels*)).

A exatidão da seleção do membro final influencia o sucesso da aplicação da Análise de Mistura Espectral, sendo que se esses não corresponderem à sua componente física, os resultados estarão incorretos. Os membros finais podem ser selecionados de cinco formas: 1) de uma biblioteca espectral, ou reflectâncias medidas na superfície; 2) da própria imagem (Settle e Drake, 1993); 3) de *pixels* espectralmente puros, obtidos

através do índice de pureza espectral; 4) da seleção manual decorrente de uma visualização multidimensional que permita a exploração e identificação de possíveis membros finais; e 5) da combinação dos métodos utilizados para obter os membros finais de referência e da imagem.

A AME implica haver correspondência espectral entre os membros finais de referência e de imagem e uma calibração que os relacione (Roberts *et al.*, 1993). Os membros finais da imagem mais facilmente identificados e os seus espectros medidos possuem a mesma escala que a imagem, e portanto são os mais utilizados na AME. (Roberts *et al.*, 1998).

Num diagrama triangular de uma imagem os extremos do triângulo representam os membros finais, que neste estudo são a vegetação, solo e impermeável. Estes podem ser identificados num diagrama de dispersão de duas bandas espectrais. Como não existiam membros finais de referência para a área de estudo, optou-se pela utilização dos membros finais da imagem na fase da AME.

A componente vegetação é facilmente identificada em terrenos agrícolas, florestais e jardins, enquanto o impermeável é representada por áreas residenciais, industriais e comerciais e a componente solo nas áreas reconversão para urbano, de agricultura em fase de pousio, ou onde não exista ou pouca existência de vegetação.

A figura 16 apresenta as assinaturas espectrais dos três componentes, para as imagens Sentinel2 e LandSat8. É possível observar que a melhoria da resolução espacial favorece a distinção entre os solos e os solos impermeáveis, sendo esta um dos maiores desafios em Deteção Remota. Porém, deve-se ter em consideração a resolução espectral de cada banda utilizada, visto que um satélite com melhor resolução espacial pode conter bandas com baixa amplitude de onda reduzindo a capacidade de separabilidade espectral.




Figura 16 - Assinaturas espectrais dos componentes do solo para as imagens de satélite Sentinel2 (a) e LandSat8 (b)

Na Figura 17 estão as imagens correspondentes aos componentes VIS das imagens de LandSat8 e Sentinel2. Como foi explicado na fase da definição dos componentes, as áreas que correspondem a vegetação são os campos agrícolas e florestais. As áreas impermeáveis correspondem essencialmente a áreas residenciais ou de extração de minério. A componente solo, como anteriormente foi dito representa predominantemente as áreas de solo a descoberto como áreas agrícola em fase de pousio.

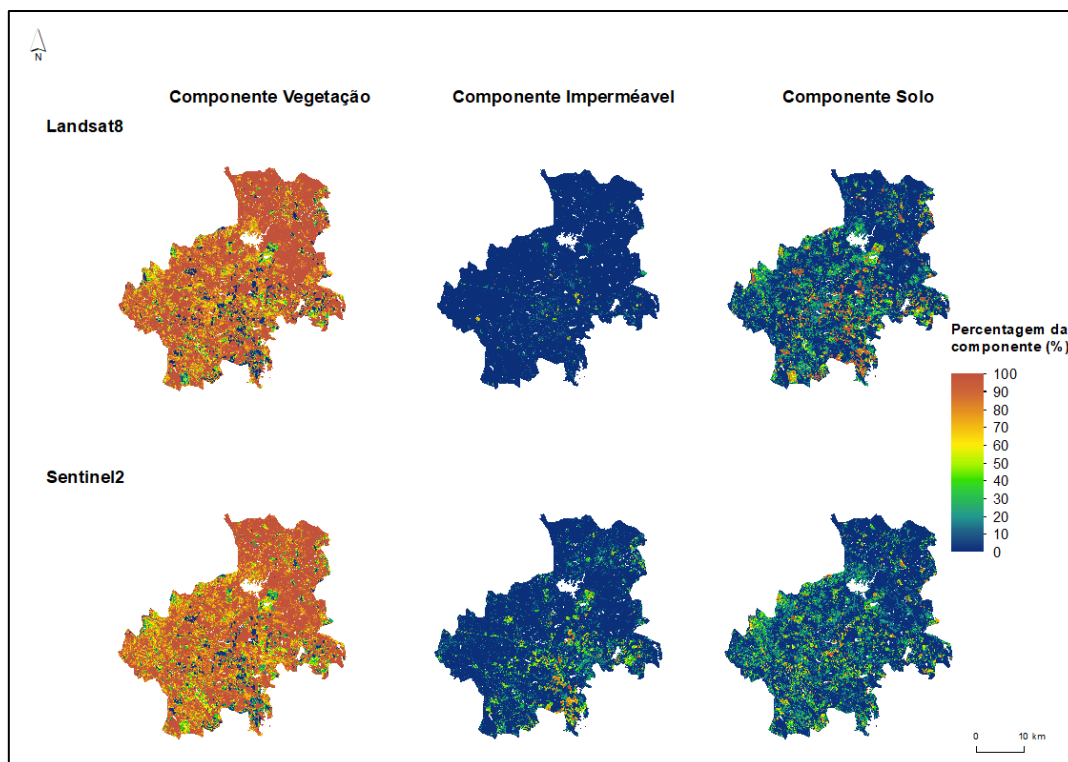


Figura 17 - Componentes VIS das imagens LandSat8 e Sentinel2

Os tons alaranjados/avermelhados (tons quentes) representam pixéis mais próximos da pureza espectral ou até mesmo poderão ser considerados membros finais. Estes estão distribuídos espacialmente por toda a área de estudo. Os tons mais “frios” representam pouca probabilidade de pertença do componente naquele *pixel*. De modo geral, estes tons são predominantes quando analisamos a componente impermeável, em ambas classificações. Importante salientar que a soma das percentagens de pertença dos três componentes é sempre 100%.

A componente solo está mais presente na área central da área de estudo, em pequenas dimensões de aglomeração. Os pixéis mais azulados no estudo da componente vegetação nas classificações representam a maior probabilidade de pertença a outras componentes.

Nas restantes áreas deste componente, visualmente parece não haver muita diferença entre resultados nas duas classificações, o que se conclui que a confusão espectral existe, essencialmente entre as restantes componentes.

Através da análise dos mapas da Figura 17 consegue-se verificar que, em termos comparativos, na classificação da imagem de satélite Sentinel2 existem mais *pixels* com a probabilidade de pertença ao impermeável do que na classificação da imagem do LandSat8. Claramente, a maioria dos *pixels* podem ser considerados como vegetação, devido à elevada probabilidade de pertença a esta ocupação, como verificamos na figura.

3.4 Análise de uso e ocupação do solo

Através da análise dos resultados demonstrados na Figura 18 e na Tabela 5 podemos verificar a quantidade de *pixels* impuros presentes, em cada imagem, após a classificação. Isto quer dizer que na classificação, estes *pixels* representam mais do que um uso na sua superfície abrangida. Devido à resolução espacial dos satélites serem diferentes, o número de *pixels* para cobrir uma determinada área é igualmente diferente. O satélite Sentinel2 apresenta uma resolução espacial de 10 metros e o LandSat 8 de 30 metros, sendo assim, o Sentinel2 apresenta uma matriz com mais linhas e colunas.

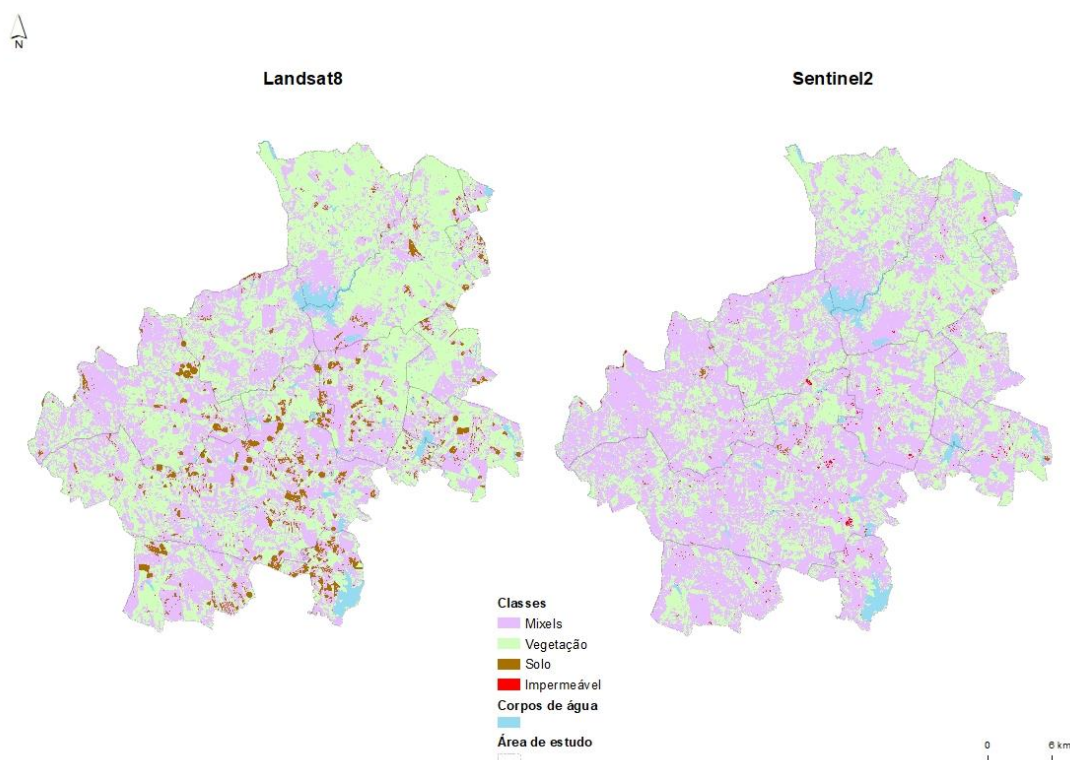


Figura 18 - Resultados da classificação com a distinção de pixels puros e mixeils

Na Tabela 5 verifica-se que existe mais *pixels* impuros na classificação da imagem do satélite Sentinel2, que poderá ser explicado pela resolução radiométrica que é menor do que a do satélite LandSat8, ou seja a sua capacidade de distinguir os objetos à superfície seria menor, originando uma maior confusão espectral.

Tabela 5 - Análise do comportamento espectral dos *pixels* decorrente da classificação

Classes	Sentinel2			LandSat8		
	<i>Pixels</i> (nº)	Área (ha)	Área (%)	<i>Pixels</i> (nº)	Área (ha)	Área (%)
<i>Mixels</i>	1 698 558	67 942,32	59,25	1 142 260	51 401,7	44,83
Vegetação	2 304 854	46 097,08	40,20	649 958	58 496,22	51,02
Solo	30 144	401,92	0,35	158 013	4 740,39	4,13
Impermeável	23 112	231,12	0,20	1 136	25,56	0,02
Total	4 056 668	114 672,4	100,00	1 951 367	114 663,9	100,00

A soma dos *pixels* admitidos como vegetação, solo e impermeável é a quantidade de *pixels* puros existentes (Tabela 6). Estes *pixels* foram considerados como tendo apenas

uma ocupação do solo na totalidade da sua superfície abrangida. Depreende-se que a área ocupada pela vegetação continua ser a maior em ambos os casos, seguindo-se o solo e o impermeável, correspondentemente.

Tabela 6 - Diferenças entre as classificações de imagens de satélite LandSat8 e Sentinel2

Classes	Classificação LandSat8	% da área total LandSat8	Classificação Sentinel2	% da área total Sentinel2
Vegetação	102 239,01	89,16	102 498,36	89,38
Impermeável	355,05	0,31	5 002,72	4,36
Solo	12 069,81	10,53	7 171,36	6,25
Total	114 663,87	100,00	114 672,44	100,00

Entre as classes de solo e impermeável existe um desfasamento maior, relativamente à sua área, na classificação das imagens. Através da ferramenta Highest Position do Spatial Analyst Tools (Local) do software ArcGIS, conseguiu-se definir a que classe pertence cada *mixel*, de acordo com a sua percentagem de pertença, ou seja é atribuída a cada *pixel* a classe predominante existente na sua composição.

Depois de cada *mixel* ter sido avaliado e lhe ter sido atribuído uma ocupação predominante, pode-se analisar a classificação, na sua totalidade. Como era previsto a vegetação é a classe predominante em ambas as classificações, perfazendo cerca de 89% da área total de estudo.

Conforme referenciado anteriormente, a confusão entre impermeável e solo é bastante significativa apesar que em ambos, o solo prevalece sobre o impermeável, porém esta diferença entre estes usos é menor na classificação de imagem de satélite Sentinel2, o que não quer dizer este seja o mais representativo da realidade.

Na Figura 19 está representado a distribuição espacial dos resultados das classificações, onde se verificou que a diferença entre as classificações das imagens assenta principalmente no facto da atribuição na classificação da imagem Sentinel2, de uso impermeável, em áreas que na classificação de LandSat8 eram solos.

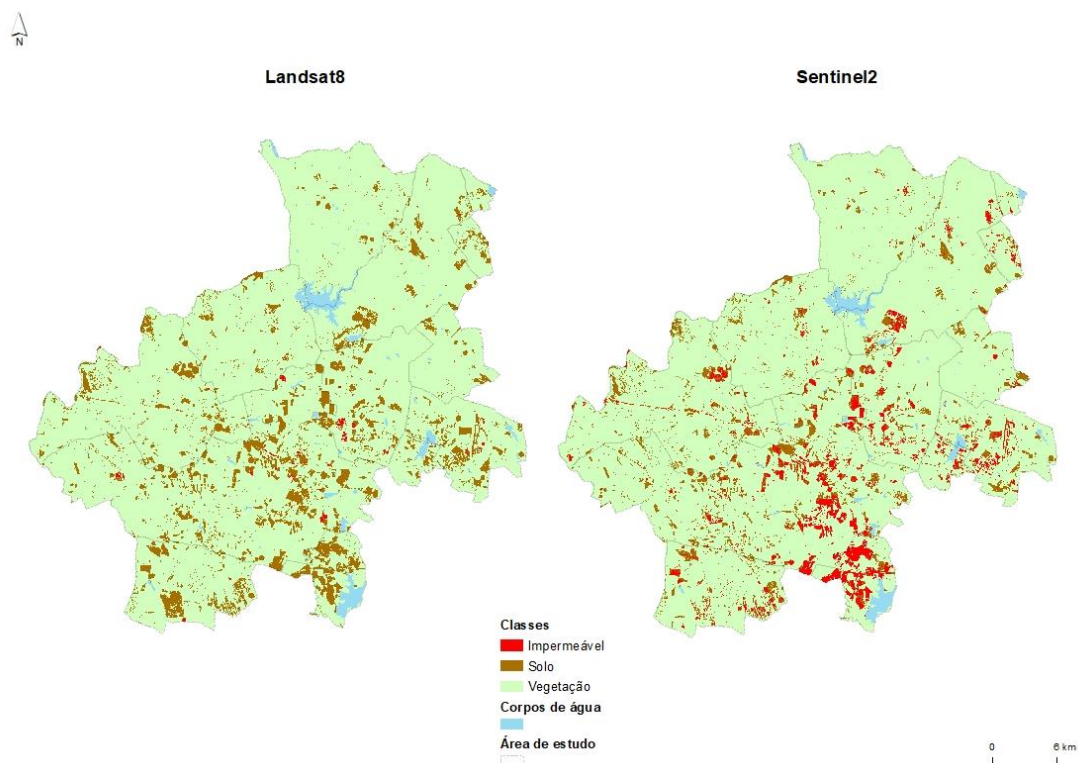


Figura 19 - Resultados finais obtidos após a classificação

Para facilitar a análise dos diagramas das figuras Figura 20, Figura 21 e Figura 22, a tabela 7 relaciona os códigos com as freguesias correspondentes.

Tabela 7 - Quadro de referência de códigos e respetivas freguesias

Código	Freguesia
1	São João de Negrilhos
2	Ervidel
3	Beringel
4	União das freguesias de Trigaches e São Brissos
5	União das freguesias de Ferreira do Alentejo e Canhestros
6	União das freguesias de Alfundão e Peroguarda
7	Figueira dos Cavaleiros
8	Faro do Alentejo
9	Odivelas
10	Vila Ruiva
11	Alvito
12	Vila Nova da Baronia

O diagrama triangular permite-nos ter noção onde se localizam as áreas em termos de conjugação das percentagens de componentes. Claramente, a área de estudo não se caracteriza como urbana. O modelo VIS, sendo principalmente aceite para áreas urbanas e de transição onde existe um *continuum* urbano, pode também estudar estas áreas, visto que a vegetação e o solo são componentes predominantes. A área de estudo apresenta alguns aglomerados urbanos pertencentes às sedes de freguesias, mas não são significativas relativamente à área total de estudo.




Figura 20 - Diagrama triangular do Modelo VIS para as freguesias - LandSat8




Figura 21 - Diagrama triangular do Modelo VIS para as freguesias - Sentinel2




Figura 22 - Variação da composição de VIS em cada classe uso devido à variação de resolução

Com a análise da Figura 22 podemos concluir que a passagem de uma resolução de 30 metros para uma de 10, provoca uma rotação, no sentido horário, da maior parte dos casos dentro do diagrama triangular. Isto reflete que a percentagem de impermeável subiu, e até se pode aferir que foi essencialmente em detrimento do solo.

Na Freguesia de Ervidel (Tabela 8), com o aumento da resolução espacial, a percentagem de solo diminuiu e aumentou a vegetação e solo impermeável, sendo esta a freguesia com mais superfície classificada como impermeável em ambas imagens. Vila Nova da Baronia representa a freguesia com maior percentagem de vegetação, tanto na classificação de imagem de satélite de LandSat8 como Sentinel2.

Tabela 8 - Percentagens da composição do Modelo VIS para cada freguesia e sua variação relativa ao aumento de resolução

	Sentinel2 (10m)			LandSat8 (30m)			Variação com a maior resolução		
Freguesia	V	I	S	V	I	S	V	I	S
São João de Negrilhos	78,24	7,49	14,26	79,05	1,02	19,93	-1,02	635,79	-28,43
Ervidel	63,01	25,37	11,62	58,51	11,38	30,10	7,69	122,83	-61,39
Beringel	80,40	11,66	7,95	77,56	8,20	14,23	3,66	42,07	-44,17
União das freguesias de Trigaches e São Brissos	80,37	8,67	10,97	79,34	3,60	17,06	1,29	140,49	-35,71
União das freguesias de Ferreira do Alentejo e Canhestros	78,42	8,22	13,37	80,25	2,06	17,69	-2,29	299,85	-24,45
União das freguesias de Alfundão e Peroguarda	81,76	8,88	9,36	82,35	2,25	15,04	-0,72	295,22	-39,24
Figueira dos Cavaleiros	81,68	3,75	14,57	84,33	0,61	15,06	-3,14	517,92	-3,31
Faro do Alentejo	88,92	2,00	9,09	89,51	0,73	9,77	-0,66	175,13	-6,95
Odivelas	85,74	2,58	11,68	87,22	1,55	11,23	-1,69	66,55	3,96
Vila Ruiva	85,76	7,70	6,54	81,39	3,04	15,57	5,37	153,43	-57,99
Alvito	89,25	4,32	6,43	88,02	2,64	9,34	1,39	63,6	-31,13
Vila Nova da Baronia	92,70	2,13	5,16	91,4	3,11	5,49	1,42	-31,35	-5,94

Onde se notou maior alteração na percentagem de um componente foi em São João de Negrilhos, onde em temos comparativos das imagens o impermeável diferiu bastante entre a classificação da imagem de Sentinel2 e LandSat8. Neste caso, o aumento da resolução traduziu-se num aumento da percentagem de impermeável. Porém, estas áreas podem não corresponder na realidade a impermeável. Ao confrontar a classificação com a fotointerpretação, verifica-se que nem sempre existe correspondência.

No geral, conclui-se que quanto maior for a resolução, maior a probabilidade de um *pixel* ser considerado impermeável em vez de solo, apesar destes dois não serem facilmente

distinguidos espectralmente. A importância da dimensão do *pixel* é comprovada na classificação de imagens de satélite em geral e na análise dos componentes VIS em particular.

3.5 Comparação entre os resultados e a COS 2018

A Carta de Uso e Ocupação do solo (COS) de Portugal Continental para 2018 é elaborada pela Direção Geral do Território (DGT), iniciando-se em 1990 e havendo atualizações para os anos 1995, 2007, 2010, 2015 e 2018. Para a produção da COS2018 a nomenclatura da COS foi reformulada no âmbito de um grupo de trabalho da Comissão Nacional do Território (CNT) coordenado pela DGT e que reuniu entidades relevantes nos domínios do uso e da ocupação do solo.

A nomenclatura inclui 83 classes, mais 35 classes do que a anterior COS (2015), sendo os níveis de desagregação reajustados. A nomenclatura obedece a uma hierarquia que representa a ocupação/uso do solo em diferentes níveis de detalhe temático. Nesta organização hierárquica as classes de nível mais detalhadas estão contidas nas classes de menor detalhe, sendo portanto abrangidas pelas definições destas últimas. A organização dos níveis de detalhe alterou-se para o primeiro nível de detalhe ter 9 classes de ocupação/uso do solo: Territórios artificializados, Agricultura, Pastagens, Superfícies agroflorestais, Florestas, Espaços descobertos ou com vegetação esparsa, Zonas húmidas e Massas de água superficiais, que correspondem às Megaclasses.

A produção da COS2018 enquadra-se na estratégia da DGT para disponibilizar informação sobre o uso e ocupação do solo com regularidade e fiabilidade através de processos de produção mais eficientes e tecnologicamente mais evoluídos, diminuindo o tempo entre o ano da aquisição dos dados base (por exemplo: fotografia aérea) e o ano da disponibilização da informação produzida ao público. A COS2018 foi produzida em 9 meses e pela primeira vez a COS é disponibilizada no ano seguinte à aquisição dos ortofotomapas utilizados na sua produção, o que se traduz numa maior representatividade da realidade do presente. Na elaboração da COS 2018 foram

considerados os limites da Carta Administrativa Oficial de Portugal (CAOP) na versão de 2018.

A COS2018 foi produzida, essencialmente, por interpretação visual de ortofotos (Tabela 9) com quatro bandas espectrais (azul, verde, vermelho e infravermelho próximo) e uma resolução espacial de 25 cm. Foram utilizadas bases de dados auxiliares provenientes de fontes diversas (Tabela 10), incluindo séries multi-temporais de imagens de satélite, no processo de produção e controlo de qualidade.

Tabela 9 - Características dos ortofotos

(Extraído do documento DGT, 2019. Especificações técnicas da Carta de Uso e Ocupação do Solo (COS) de Portugal Continental para 2018)

Ano 2018	
Direitos de propriedade	DGT/IFAP/ICNF
Câmara	DMC129 e UltraCam Falcon
Altura de voo	3200 m (DMC129) e 4300 m (UltraCam Falcon)
Formato das imagens	TIFF
Seccionamento	4 km × 2,5 km
Resolução espacial	0,25m no terreno
Resolução radiométrica	8 bits por banda
Resolução espectral	RGB e Infravermelho próximo
Sistema de georreferência	ETRS89/PT-TM06
Datas dos ortofotos	Junho, julho, agosto, setembro, outubro 2018

Tabela 10 - Dados auxiliares utilizados na produção da COS

(Extraído do documento DGT, 2019. Especificações técnicas da Carta de Uso e Ocupação do Solo (COS) de Portugal Continental para 2018)

Tema	Proprietário	Data de referência
Ortofotos digitais com uma resolução de 0,5 m	DGT/DGRF	2004/2006
Ortofotos digitais com uma resolução de 0,5 m	DGT/IFAP	2012
Carta de ocupação do solo para 1990 (COS'90)	DGT	1990
CORINE Land Cover	DGT	1990, 2000, 2006, 2012 e 2018
Pontos de campo do Land Use/Cover Area frame Survey (LUCAS)	EUROSTAT	2009, 2012 e 2015
Cartografia anual de áreas ardidas	ICNF	1990 a 2018
Fotopontos e parcelas de campo do Inventário Florestal Nacional	ICNF	1995, 2005/2006 e 2010
Inventário Nacional Florestal	ICNF	1970
Sistema de Informação Geográfica Vitivinícola	IVV	
Cadastro olivícola	IFAP	2005
Parcelário	IFAP	2010-2018
Cartografia Florestal do Eucalipto	CELPA	1995 a 2000
Imagens de satélite AWiFS (abril, julho e outubro)	ESA	2006
Imagens de satélite AWiFS (abril até outubro)	ESA	2011
Imagens de satélite AWiFS (março, maio, junho e agosto)	ESA	2012
Imagens de satélite LISSIII (primavera e verão)	ESA	2009
Imagens de satélite SPOT5 (janeiro a setembro)	ESA	2011
Imagens Landsat		2010 a 2018
Google Earth e Google Maps	Google	
Imagens Sentinel 2	DGT	2016, 2017 e 2018
Bing Maps	Microsoft	

Atualmente a COS representa a informação mais utilizada relativamente à vertente de ocupação do solo, posicionando-se como informação de referência para a elaboração /alteração de planos nos diversos níveis administrativos. Cobrindo o território nacional continental, permite uma análise bastante detalhada e exata sobre os fenómenos que acontecem na superfície do território, sendo que nos níveis mais desagregados encontramos um maior detalhe de uso e ocupação do solo e portanto, a necessidade de comparação entre os resultados obtidos e a COS 2018 (Figura 23).

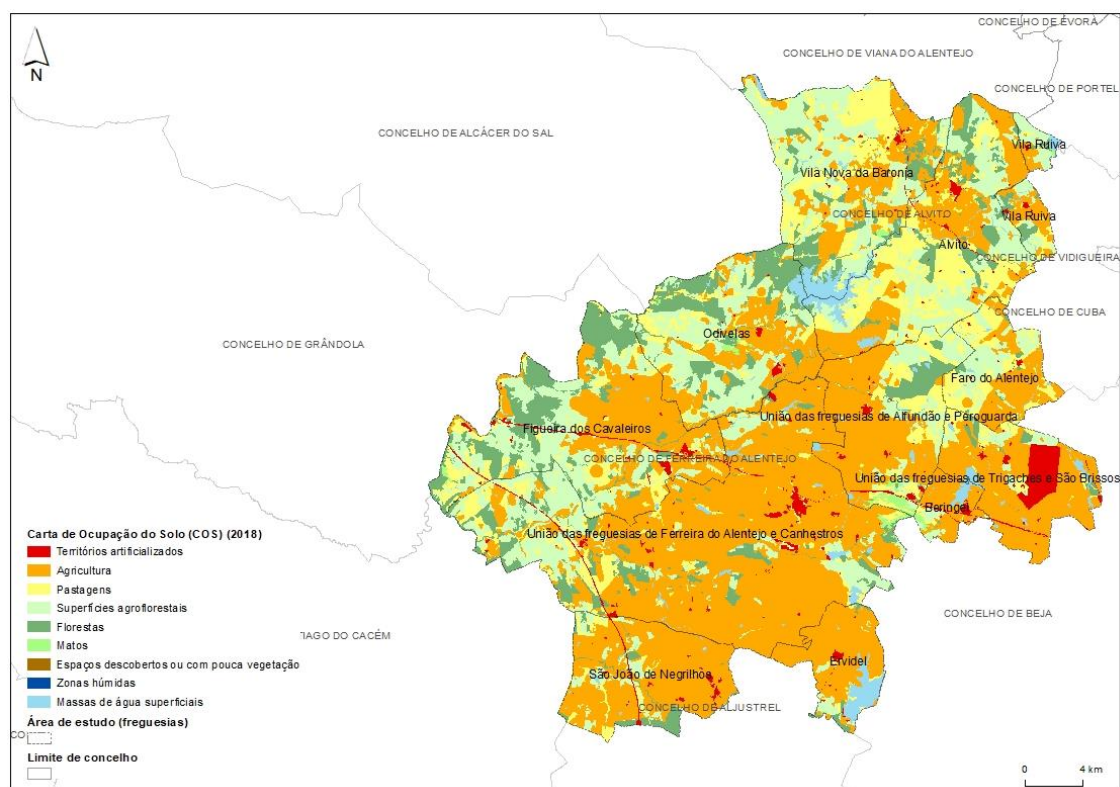


Figura 23 - Carta de Ocupação do solo (2018) nível I

Na área de estudo podemos verificar uma predominância de agricultura (49,33%), seguindo-se as superfícies agroflorestais (21,11%), perfazendo mais de 70% de toda a área (Tabela 11). Portanto prevê-se que a vegetação do modelo VIS, seja a que predomine.

Tabela 11 - Áreas das classes de Ocupação do solo na área de estudo

Classes	Área (ha)	Área (%)
Territórios artificializados	2 695,00	2,29
Agricultura	58 111,14	49,33
Pastagens	15 804,26	13,42
Superfícies agroflorestais	24 867,75	21,11
Florestas	12 542,3	10,65
Matos	648,55	0,55
Espaços descobertos ou com pouca vegetação	0,67	0,00
Zonas húmidas	1,92	0,00
Massas de água superficiais	3 131,95	2,66

Verifica-se também que as zonas húmidas e os espaços descobertos ou com pouca vegetação não são representados nenhuma significância. Os territórios artificializados apresentam cerca de 2% na área de estudo.

Para uma comparação entre os resultados obtidos e a COS 2018, foi necessária fazer uma agregação das classes no nível mais abrangente desta última e a sua correspondência com os componentes do modelo VIS. Tendo em conta as definições para cada nível, por parte da DGT, (Tabela 12) procedeu-se então à sua correspondência. As Zonas húmidas e Massas de água superficiais não foram completadas devido à exclusão das mesmas no processo de classificação.

A tabela 13 representa a correspondência entre os componentes do modelo VIS e as classes da COS 2018, nível I.

A Figura 24 representa espacialmente a distribuição de cada classe tendo sido já agrupadas de forma a corresponder a cada componente do modelo VIS. Claramente, a vegetação ocupa a maioria da área de estudo tal como acontecia nos resultados obtidos na classificação, seguindo-se os territórios artificializados e depois os solos com pouquíssima representatividade.

Tabela 12 - Descrição das classes da Carta de Uso e Ocupação do Solo 8

(adaptado de DGT, 2019. Especificações técnicas da Carta de Uso e Ocupação do Solo (COS) de Portugal Continental para 2018)

	Classe	Descrição
1	Territórios artificializados	Superfície de território destinada a atividades de intervenção humana. Esta classe inclui áreas de tecido edificado, áreas industriais, áreas comerciais, áreas dedicadas ao turismo, infraestruturas, rede rodoviária e ferroviária, áreas de serviços, jardins e equipamentos.
2	Agricultura	Área utilizada para agricultura, constituída por culturas anuais, culturas permanentes e agricultura protegida e viveiros.
3	Pastagens	Áreas com ou sem intervenção humana ocupadas com vegetação essencialmente do tipo herbáceo, quer cultivada (semeada) quer natural (espontânea), que não estejam incluídas num sistema de rotação da exploração e que ocupem uma área superior ou igual a 25% da superfície.
4	Superfícies agroflorestais	As superfícies agroflorestais consistem na consociação (associação vertical numa mesma parcela) de culturas temporárias e/ou pastagens (melhoradas ou espontâneas pobres) e/ou culturas permanentes com espécies florestais com um grau de coberto superior ou igual a 10%.
5	Florestas	Terrenos com uso florestal, ocupados por árvores florestais, ou temporariamente desarborizados em resultado de cortes culturais ou cortes extraordinários devidos a perturbações bióticas (pragas, doenças) ou abióticas (incêndios, tempestades). As árvores originadas por regeneração natural, sementeira ou plantação, devem atingir uma altura maior ou igual a 5 metros e no seu conjunto apresentarem um grau de coberto maior ou igual a 10%. O sobcoberto não é dedicado à agricultura (classes 4.1.1.x) nem a atividades recreativas quando inseridas num contexto urbano (classe 1.7.1.1). Estão incluídos os terrenos ocupados por árvores florestais, vivas ou mortas, resultantes de regeneração natural, sementeira ou plantação, cortes rasos, novas plantações florestais e superfícies recentemente afetadas por incêndios florestais em processo de regeneração há menos de 5 anos.
6	Matos	Áreas naturais de vegetação espontânea, pouco ou muito densa, em que o coberto arbustivo (e.g., urzes, silvas, giestas, tojos, zambujeiro) é superior ou igual a 25%. Inclui olivais abandonados se inferior a 45 árvores/ha.
7	Espaços descobertos ou com pouca vegetação	Áreas naturais com pouca ou nenhuma vegetação em que se incluem rocha nua, praias e areais e vegetação esparsa em que a superfície com vegetação arbustiva e herbácea ocupa uma área inferior a 25%

Tabela 13 - Correspondência entre as classes do Modelo VIS e da COS 2018 (nível I)

Modelo VIS	Classes da COS 2018
Vegetação	Agricultura, Pastagens, Superfícies Agroflorestais, Florestas e Matos
Impermeável	Territórios Artificializados
Solo	Espaços descobertos ou com pouca vegetação

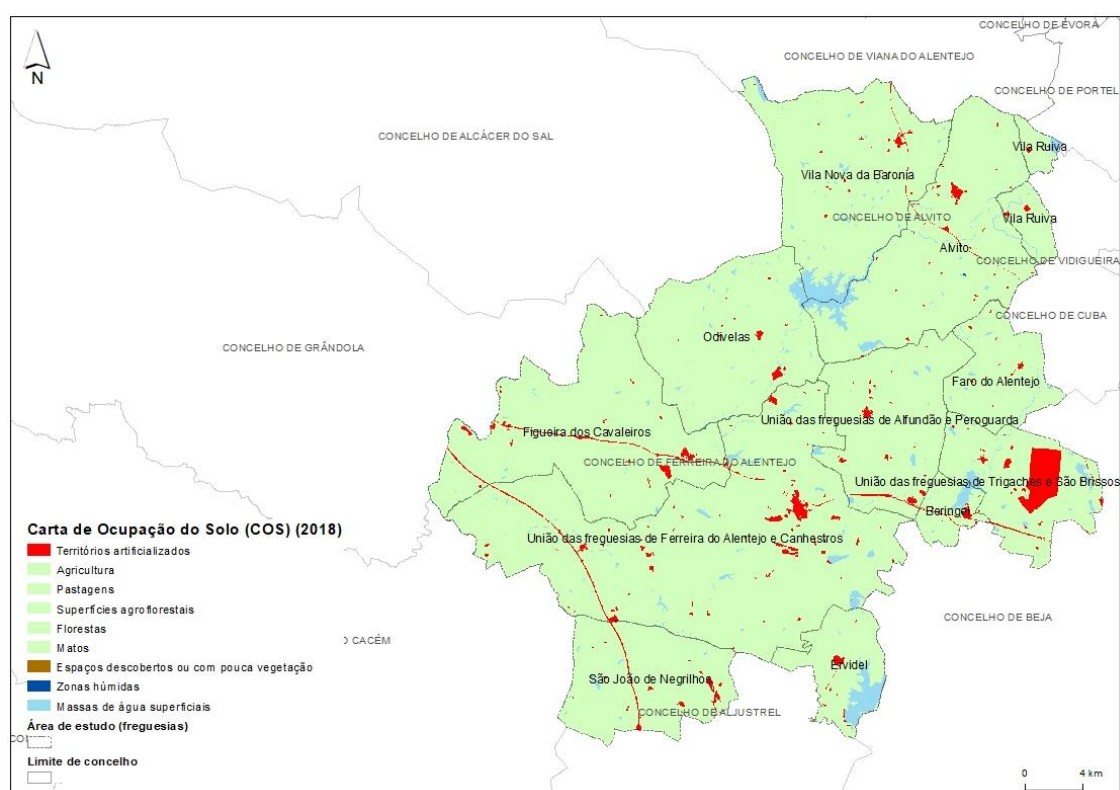


Figura 24 - Carta de Ocupação do solo (2018) nível I de acordo com a agregação das classes para comparação com o Modelo VIS

A análise da Tabela 14 permite-nos fazer uma comparação entre os resultados obtidos em ambas classificações, LandSat8 e Sentinel2 e a COS2018.

Tabela 14 - Comparação entre os valores obtidos pela classificação e classes da COS 2018 (ha)

Componente	Classificação LandSat8	Classificação Sentinel2	COS2018
Vegetação	102 239,01	102 498,36	111 974
Impermeável	355,05	5 002,72	2 695
Solo	12 069,81	7 171,36	0,67
Total	114 663,87	114 672,44	114 669,7

Apesar da quantidade de vegetação não variar muito, não se aplica o mesmo para as classes de solo e impermeável, onde existem as maiores diferenças. A confusão espectral entre estas duas componentes é a causa desta diferença tão grande com a COS2018 e entre as classificações das duas imagens de satélite.

Com isto, é um pouco precipitado dizer-se qual classificação ao nível do subpixel, é a mais aproximada à COS2018. Porém como a classificação da imagem de Sentinel2, apresenta valores tão díspares nas componentes de solo e impermeável, relativamente aos valores da COS, podemos concluir que nem sempre a melhoria da resolução espacial se traduz numa melhor adaptação à realidade, sendo que esta deve ser tida em conta, numa primeira análise face à dimensão dos fenómenos que se pretende estudar.

Acrescenta-se ainda que a informação auxiliar e multi-temporal ajudou a densificar a exatidão do resultado final da COS 2018, o que não aconteceu na Análise da Mistura Espectral, que no entanto pode-se considerar que serviu o propósito.

4 Considerações finais

As paisagens rurais são menos complexas que as urbanas, mas são igualmente difíceis de classificar. A AME demonstrou neste estudo que é uma abordagem válida também para caracterizar os padrões de uso e ocupação do solo, em áreas rurais. Estes usos tendem a ser compostos por misturas espectrais heterogêneas, embora menos do que nas áreas urbanas.

Podemos considerar que o aumento da resolução espacial reflete um aumento do custo de aquisição e de processamento e da variação espectral dos tipos de uso e ocupação do solo, levando a que exista um decréscimo da separabilidade espectral das classes e assim, à redução na exatidão das classificações.

Verifica-se, neste estudo, que através da AME é possível identificar as classes de uso e ocupação do solo ao nível da freguesia. O fator resolução espacial apresenta-se como importante, porém não é o único que influencia nos resultados, visto que os resultados obtidos pelas imagens de satélite LandSat8 (30 metros) parecem mais fáceis de interpretar ou justificar. Tendo em conta, o conhecimento desta área de estudo, conclui-se que no Sentinel2 (10 metros) houve uma maior confusão espectral entre os solos e o impermeável. Nas áreas urbanizadas, percebe-se uma melhor correspondência, representando de forma mais real os limites destas áreas, porém no resto do território muitos *pixels* foram considerados impermeáveis enquanto deveriam ser solos.

O modelo VIS comprovou ser um suporte válido para a AME. As imagens resultantes fornecem informação ao nível do *subpixel* sobre cada componente do modelo VIS. Isto permite uma representação simplificada de áreas heterogêneas como componentes básicos do solo, permitindo uma avaliação quantitativa, para além da perspetiva qualitativa. A imagem resultante dos classificadores ao nível do *subpixel* oferece mais informação e mais fidedigna do que os classificadores pixel-por-pixel. Os classificadores

subpixel podem ser bastante úteis para estudos relacionados com alterações de uso, crescimento da área florestal, entre outros.

O modelo VIS apesar ter demonstrado ser útil para a identificação dos padrões do uso do solo, peca por alguns fatores práticos se apresentarem como constrangimentos. Nesta área de estudo existiam vários corpos de água e zonas húmidas que o modelo VIS não contempla. Provavelmente, um modelo VIS mais água seria uma boa aposta e mais completa para a interpretação deste tipo de áreas. Em resoluções espaciais médias como a do Sentinel2, o solo a descoberto e o impermeável são difíceis de distinguir. O impermeável, por ser composto por uma mistura complexa de diferentes materiais (asfalto, argila, betão, metal, etc.), e é difícil identificar como membro final numa análise de imagem de satélite.

Um fator que o modelo VIS exclui e que é uma peça importante é a sombra presente nos *mixels*. Esta sombra deriva da altura dos edifícios, árvores ou arbustos e tem uma influência direta na resposta espectral dos tipos de uso e ocupação do solo.

Seria interessante fazer esta análise noutras alturas do ano, nomeadamente nas outras estações do ano, visto que a situação na superfície terrestre muda e sendo assim as características espectrais também. Prevê-se que a alteração seria essencialmente entre vegetação e solo porque são estes que dependem da ocupação mais predominante nesta área, que é a agricultura. Esta análise permitiria verificar o efeito da sazonalidade ao longo do ano e o seu efeito na classificação.

Uma classificação satisfatória a partir de uma imagem obtida por deteção remota depende de alguns fatores que influenciam de forma direta os resultados, tais como: a complexidade das paisagens da área de estudo, a existência de dados adequados, usos apropriados de variáveis e algoritmos de classificação, a experiência do analista entre outros.

5 Bibliografia

- Adams, J.B., D.E. Sabol, V. Kapos, R.A. Filho, D.A. Roberts, M.O. Smith, e A.R. Gillespie, (1995). Classification of multispectral images based on fractions of endmembers: application to land cover change in the Brazilian Amazon, *Remote Sensing of Environment*, 52:137–154.
- Bateson, A., e B. Curtiss, (1996). A method for manual endmember selection and spectral unmixing, *Remote Sensing of Environment*, 55:229–243.
- Boardman et al., 1995
- DGT, 2019. Especificações técnicas da Carta de Uso e Ocupação do Solo (COS) de Portugal Continental para 2018
- Gilabert, M. A., Garcia-Haro, F. J., & Melia, J. (2000). A mixture modeling approach to estimate vegetation parameters for heterogeneous canopies in remote sensing. *Remote Sensing of Environment*, 72, 328– 345.
- Haack, B.N., E.K. Solomon, M.A. Bechdol, e N.D. Herold, (2002). Radar and optical data comparison/integration for urban delineation: a case study, *Photogrammetric Engineering and Remote Sensing*, 68:1289-1296.
- Harris, P.M., e S.J. Ventura, (1995). The integration of geographic data with remotely sensed imagery to improve classification in an urban area, *Photogrammetric Engineering and Remote Sensing*, 61:993-998.
- Jensen, J.R. (2005) *Introductory Digital Image Processing: A Remote Sensing Perspective*. Prentice-Hall, Englewood Cliffs, New Jersey, USA, 379 p.
- Kauth, R. J., & Thomas, G. S. (1976). The tasseled cap—a graphic description of the spectral- temporal development of agricultural crops as seen by Landsat. *Proceedings of the Symposium on Machine Processing of Remotely Sensed Data* (pp. 4041– 4051).
- Lu, Weng (2004) - Spectral Mixture Analysis of the Urban Landscape in Indianapolis City with Landsat ETM+ Imagery, *Photogrammetric Engineering & Remote Sensing*.
- Lu, Weng (2007) - A survey of image classification methods and techniques for improving classification performance, *International Journal of Remote Sensing*.
- Matos, J., (2016) *Fundamentos de Informação Geográfica*, Lidel, 6ª edição

- Myint, S.W., (2001). A robust texture analysis and classification approach for urban land-use and land-cover feature discrimination, *Geocarto International*, 16:27-38.
- Richardson, A. J. e Wiegand, C. L. (1977). Distinguishing vegetation from soil background information. *Remote Sensing of the Environment*, 8, 307-312.
- Ridd, M.K. (1995). Exploring a V-I-S (Vegetation-Impervious Surface-Soil) model for urban ecosystem analysis through remote sensing: Comparative anatomy for cities. *International Journal of Remote Sensing*, 16(21):2165-2185.
- Roberts, D. A., Smith, M. O., & Adams, J. B. (1993). Green vegetation, nonphotosynthetic vegetation, and soil in AVIRIS data. *Remote Sensing of Environment*, 44, 255–269.
- Roberts, D.A., G.T. Batista, J.L.G. Pereira, E.K. Waller, e B.W. Nelson, (1998a). Change identification using multitemporal spectral mixture analysis: applications in eastern Amazônia, *Remote Sensing Change Detection: Environmental Monitoring Methods and Applications* (R.S. Lunetta and C.D. Elvidge, editors), Ann Arbor Press, Ann Arbor, Mich., pp. 137–161.
- Roberts, D.A., M. Gardner, R. Church, S. Ustin, G. Scheer, e R.O. Green, (1998b), Mapping chaparral in the Santa Monica mountains using multiple endmember spectral mixture models, *Remote Sensing of Environment*, 65:267-279.
- Rocha, J., Sousa, P.M., (2007), Integração de dados estatísticos na classificação de Imagens de Satélite, *Estudos para o Planeamento Regional e Urbano* nº 70, Centro de Estudos Geográficos, Universidade de Lisboa.
- Schoenmakers, R.P.H.M. (1995) Integrated methodology for segmentation of large optical satellite images in land applications of remote sensing. PhD thesis, Department of Informatics, University of Nijmegen, The Netherlands.
- Settle, J.J., e N.A. Drake, (1993). Linear mixing and the estimation of ground cover proportions, *International Journal of Remote Sensing*, 14:1159–1177.
- Tenedório, J.A., Rocha J., Encarnação, S., e Sousa, P.M., (2007). Classificação de uso do solo urbano através da análise linear de mistura espectral com imagens de satélite. Centro de Estudos Geográficos.

Zhang, J., e G.M. Foody, (2001). Fully-fuzzy supervised classification of sub-urban land cover from remotely sensed imagery: statistical neural network approaches, *International Journal of Remote Sensing*, 22:615-628.